


## Uso de dados multiespectrais e hiperespectrais na detecção, medição e diagnóstico de doenças na agricultura





*Empresa Brasileira de Pesquisa Agropecuária  
Embrapa Informática Agropecuária  
Ministério da Agricultura, Pecuária e Abastecimento*

# ***Documentos 134***

## **Uso de dados multiespectrais e hiperespectrais na detecção, medição e diagnóstico de doenças na agricultura**

*Jayme Garcia Arnal Barbedo*

Embrapa Informática Agropecuária  
Campinas, SP  
2015

## **Embrapa Informática Agropecuária**

Av. André Tosello, 209 - Barão Geraldo

Caixa Postal 6041 - 13083-886 - Campinas, SP

Fone: (19) 3211-5700

www.embrapa.br/informatica-agropecuaria

SAC: www.embrapa.br/fale-conosco/sac/

### **Comitê de Publicações**

Presidente: *Giampaolo Queiroz Pellegrino*

Secretária: *Carla Cristiane Osawa*

Membros: *Adhemar Zerlotini Neto, Stanley Robson de Medeiros Oliveira, Thiago Teixeira Santos, Maria Goretti Gurgel Praxedes, Adriana Farah Gonzalez, Neide Makiko Furukawa, Carla Cristiane Osawa*

Membros suplentes: *Felipe Rodrigues da Silva, José Ruy Porto de Carvalho, Eduardo Delgado Assad, Fábio César da Silva*

Supervisor editorial: *Stanley Robson de Medeiros Oliveira, Neide Makiko Furukawa*

Revisor de texto: *Adriana Farah Gonzalez*

Normalização bibliográfica: *Maria Goretti Gurgel Praxedes*

Editoração eletrônica/Arte capa: *Neide Makiko Furukawa*

Imagens capa: *Jayme Garcia Arnal Barbedo*

### **1ª edição**

publicação digital 2015

#### **Todos os direitos reservados.**

A reprodução não autorizada desta publicação, no todo ou em parte, constitui violação dos direitos autorais (Lei nº 9.610).

#### **Dados Internacionais de Catalogação na Publicação (CIP) Embrapa Informática Agropecuária**

---

Barbedo, Jayme Garcia Arnal.

Uso de dados multiespectrais e hiperespectrais na detecção, medição e diagnóstico de doenças na agricultura / Jayme Garcia Arnal Barbedo. - Campinas : Embrapa Informática Agropecuária, 2015.

31 p. : il. ; cm. - (Documentos / Embrapa Informática Agropecuária, ISSN 1677-9274; 134).

1. Hiperespectral. 2. Multiespectral. 3. Diagnóstico de doença. 4. Imagem digital. I. Embrapa Informática Agropecuária. II. Título. III. Série.

CDD 621.3678 (21.ed.)

# Autor

## **Jayme Garcia Arnal Barbedo**

Engenheiro eletricitista, doutor em Engenharia Elétrica, pesquisador da Embrapa Informática Agropecuária, Campinas, SP



# **Apresentação**

A aplicação do processamento digital de imagens e visão computacional na agricultura vem ganhando cada vez mais adeptos. Dentre as áreas com maior potencial de se beneficiar de ferramentas deste tipo, destaca-se a detecção, a medição e a identificação de doenças em plantas, uma vez que as análises manuais ainda largamente utilizadas normalmente são demoradas e sujeitas a erros ligados à subjetividade do processo.

Idealmente, os métodos para detecção e identificação de doenças deveriam ser baseados no uso de imagens convencionais no espectro visível, uma vez que câmeras capazes de fornecer imagens com qualidade razoável estão se tornando cada vez mais comuns, especialmente de forma embarcada em dispositivos de telefonia móvel. Contudo, em muitos casos o problema exige informações que vão além daquelas presentes numa fotografia convencional, fazendo com que outros mecanismos precisem ser adotados para que resultados satisfatórios possam ser alcançados.

Dentre as abordagens alternativas que vêm sendo adotadas, imagens e reflectâncias multiespectrais e hiperespectrais têm se destacado como ferramentas poderosas. Cada imagem desse tipo é, na verdade, composta por uma série de imagens revelando a reflectância observada em vários comprimentos de onda, na maioria das vezes cobrindo a faixa que vai do espectro visível até o infravermelho próximo. Cada uma dessas faixas tem o potencial de detectar sinais característicos das doenças que não são visíveis em outras bandas espectrais.

Este trabalho tem por objetivo descrever algumas das principais técnicas usando imagens e reflectâncias multiespectrais e hiperespectrais aplicadas à detecção e ao diagnóstico de doenças, fornecendo também algumas perspectivas futuras para esta área de pesquisa.

***Silvia Maria Fonseca Silveira Massruhá***

Chefe-geral

Embrapa Informática Agropecuária





# Sumário

Levantamento bibliográfico.....	9
Discussão.....	23
Conclusão .....	25
Referências .....	25



# Uso de dados multiespectrais e hiperespectrais na detecção, medição e diagnóstico de doenças na agricultura

---

*Jayme Garcia Arnal Barbedo*

## Levantamento bibliográfico

As referências apresentadas a seguir foram divididas de acordo com a maneira como os dados espectrais foram capturados. Imageamento multiespectral se refere aos casos em que são capturadas imagens em algumas poucas bandas espectrais (muitas vezes apenas três ou quatro) correspondendo ao azul, ao verde, ao vermelho e ao infravermelho próximo. Imageamento hiperespectral se refere aos casos em que imagens em diversas bandas são capturadas, em uma faixa de comprimentos de onda que normalmente vão do visível ao infravermelho próximo ou médio. Por fim, reflectância hiperespectral se refere aos casos em que a radiação espectral refletida pelos dosséis ou folhas individuais de plantas é analisada em vários comprimentos de onda.

### Imageamento Multiespectral

Kraft et al. (1996) testaram o uso de imagens capturadas por uma câmera pancromática (450-950 nm) para detectar danos invisíveis causados por ozônio em lavouras. A partir de imagens ou autores, calcularam o Normalized Difference Vegetation Index (NDVI), índice normalizado de diferença de vegetação, e o ponto de inflexão principal, os quais foram usados

para detectar os danos. Testes realizados com milho, trigo de primavera e trevo branco indicaram a possibilidade de se utilizar esta abordagem.

Aleixos et al. (2002) empregaram quatro bandas da faixa visível e do infravermelho, bem como um mecanismo composto de esteira e de uma iluminação especial, para detectar defeitos em citros; os autores reportaram que o sistema tem alta capacidade de detecção de problemas nas frutas, sendo capaz de processar entre 10 e 16 frutas por minuto.

Liu et al. (2006) fizeram uso de 4 bandas espectrais (azul, verde, vermelho e infravermelho) para realizar o monitoramento aéreo da morte súbita do carvalho em florestas da Califórnia. Os autores adotaram uma abordagem espaço-temporal, de maneira a extrair o máximo de informação a partir das imagens capturadas. Técnicas como Máquinas de Vetores Suporte, Campos Aleatórios de Markov e Modo Condicional Iterativo, foram usadas na classificação das imagens. Testes mostraram que a combinação das distribuições espaciais e temporais produz resultados significativamente superiores à abordagem puramente espacial.

Ariana et al. (2006) combinaram medidas de reflectância de seis bandas da faixa visível e do infravermelho ao imageamento por fluorescência para detectar e classificar diferentes tipos de defeitos em maçãs; a classificação foi realizada por redes neurais, sendo que o índice de acertos do sistema considerando cinco tipos de defeitos ficou entre 80 e 90% para as quatro variedades de maçã testadas.

Franke e Menz (2007) usaram imagens multiespectrais capturadas pelo satélite quickbird para detectar oídio e ferrugem em lavouras de trigo. Os autores usaram uma árvore de decisão, baseada no índice NDVI e na filtragem casada sintonizada para a mistura, para classificar as áreas de acordo com a severidade da doença. Eles concluíram afirmando que o esquema proposto é apenas moderadamente apropriado para detecção precoce de doenças no campo.

Hill et al. (2009) realizaram a captura de imagens aéreas da vegetação de certas áreas da Austrália em 4 bandas do espectro (3 na faixa visível e 1 no infravermelho próximo), e usaram essas imagens para a detecção da doença causada por *Phytophthora cinnamomi*. A correlação entre os

resultados fornecidos pelas imagens multiespectrais e a análise realizada manualmente em solo foi de 0,49, o que, segundo os autores, é suficiente para o propósito de controle dessa doença.

Cui et al. (2009) extraíram três parâmetros (razão da área infectada, índice de cor da lesão e índice de severidade da ferrugem) a partir de três bandas do espectro visível e infravermelho próximo para detectar e quantificar ferrugem em folhas de soja; os autores reportaram bons resultados, destacando que mais testes seriam necessários para garantir que este tipo de abordagem pode de fato ser utilizada para detecção de ferrugem em soja.

Os mesmos autores (CUI et al., 2010) propuseram um método usando as mesmas quatro bandas, sendo que aqui o foco foi dedicado ao teste de dois tipos diferentes de segmentação, um manual tendo como base o espaço de cores Matiz, Saturação e Intensidade, Hue, Saturation, Intensity (HSI) e um automático baseado no centroide da distribuição de cor da folha num sistema de coordenadas polares; os autores concluíram que o método automático tem potencial de ser usado em imagens capturadas no campo.

Bauer et al. (2011) usaram imagens capturadas através de uma câmera convencional e uma câmera multiespectral de quatro bandas para gerar um modelo tridimensional das folhas a serem analisadas, empregando as técnicas de k-vizinhos mais próximos e classificação adaptativa de Bayes para realizar a classificação; o índice de acertos observado foi ligeiramente menor que 90% na identificação de duas doenças em folhas de beterraba.

Dammer et al. (2011) compararam os resultados obtidos usando uma câmera convencional e uma câmera multiespectral de três canais na detecção de giberela em plantas de trigo no campo, por uma análise das espigas; os autores chegaram à conclusão de que o sistema multiespectral teve uma maior taxa de acertos, tendo ao mesmo tempo uma melhor capacidade de calibração em relação ao sistema usando imagens convencionais.

Oerke et al. (2011) capturaram imagens de folhas de macieiras usando um sensor operando na faixa de 8 a 12  $\mu\text{m}$ , a qual está localizada no infravermelho termal. O objetivo da análise termográfica realizada pelos autores

foi a de detectar e quantificar os danos causados pela sarna-da-macieira. Segundo os autores, os resultados obtidos foram bons, porém testes precisariam ser realizados em condições de campo para verificar seu potencial uso no monitoramento de pomares.

O objetivo de Oberti et al. (2014) foi determinar o melhor ângulo de captura para um sistema multiespectral composto de três bandas (verde, vermelho e infravermelho), tendo como aplicação a detecção automática de oídio em videiras. Segundo os autores, quanto mais inclinado é o ângulo de captura, maiores os índices de acerto e mais precoce a detecção, sendo que o pico de desempenho foi observado a 60°. A explicação para isto está relacionada ao crescimento, nos estágios iniciais da doenças, de filamentos verticais que só são detectáveis em certos ângulos.

Polder et al. (2014) usaram um sistema de imageamento multiespectral baseado em filtros de largura estreita na faixa de 500-750 nm para detectar o vírus TBV em tulipas, substituindo o sistema hiperespectral proposto anteriormente (POLDER et al., 2010). O sistema é formado por três blocos principais, segmentação, extração de atributos e classificação. O sistema proposto alcançou um índice de acerto de cerca de 90%, muito próximo daquele obtido por avaliadores humanos.

## **Imageamento Hiperespectral**

A detecção de danos em maçãs usando reflectância espectral foi o tema do artigo escrito por Miller et al. (1998). Os autores usaram imagens capturadas na faixa de 460-1130 nm, dados estes que foram usados como entrada de vários algoritmos de reconhecimento de padrões, como redes neurais multimodais, Gaussianas unimodais, K-vizinhos mais próximos, entre outros. Os melhores resultados foram obtidos pelas redes neurais artificiais.

Guyer e Yang (2000) usaram imagens espectrais na faixa de 680-1280 nm para detectar três tipos de defeitos em cerejas. A técnica proposta pelos autores consiste na submissão das assinaturas espectrais dos diferentes tecidos das cerejas, uma rede neural artificial, cuja topologia e pesos foram definidos pela aplicação de um algoritmo genético aperfeiçoado. Segundo

os autores, todos os defeitos foram corretamente detectados, e o algoritmo alcançou um índice de acerto de 73% na classificação desses defeitos.

Coops et al. (2003) propuseram a extração de diversos índices, tendo como base 10 bandas espectrais selecionadas dentre várias imagens capturadas no intervalo de 400-1000 nm, para detectar uma doença (*Dothistroma*) que se manifesta nas agulhas de pinheiros. As imagens foram obtidas através do sobrevoo de florestas de pinheiro da Austrália. Os testes realizados com essas imagens renderam bons resultados, embora os autores tenham destacado que condições de iluminação têm significativo impacto nos resultados.

Liu et al. (2005) usaram imagens hiperespectrais capturadas em 112 bandas na faixa de 447-951 nm para detectar danos causados pela refrigeração aplicada durante seu transporte e armazenamento. Segundo os autores, os resultados revelaram que tanto a razão entre as bandas de 811 nm e 756 nm quanto o modelo PCA aplicado a uma faixa espectral estreita (733 - 848 nm) foram capazes de detectar os danos em mais de 90% dos casos.

Qin et al. (2008) selecionaram quatro bandas dentre as 99 capturadas na faixa de 400-900 nm para detectar o cancro em citros. As imagens foram analisadas usando Análise de Componentes Principais (ACP), e a classificação foi baseada em operações morfológicas realizadas sobre as bandas selecionadas. O índice de acertos obtido pela proposta foi de 92,7%.

O sistema proposto por Qin et al. (2009) usa 92 bandas na faixa de 450-930 nm para detectar cancro em citros. Os autores utilizaram o método de classificação chamado “divergência de informação espectral”, Spectral Information Divergence (SID), o qual é baseado na quantificação de similaridades espectrais com base em um espectro de referência previamente determinado. Testes realizados em toranjas revelaram um índice de acerto de 96%.

Quatro diferentes tipos de técnicas foram comparadas por Polder et al. (2010) para detecção do vírus TBV em tulipas: a) imagens fotográficas convencionais; b) imagens hiperespectrais; c) reflectâncias hiperespectrais; e d) fluorescência de clorofila. Segundo os autores, o sistema usando

imagens hiperespectrais teve os melhores resultados, com uma taxa de erros apenas um pouco acima da detecção visual.

Kim et al. (2011) instalaram câmeras hiperespectrais capazes de coletar imagens na faixa de 385-1000 nm em uma estufa contendo macieiras, com o objetivo de detectar estresses hídricos nessas plantas. Os autores observaram que as maiores correlações foram obtidas com o índice de vegetação (NDVI) no limite do vermelho (705-750 nm). Os autores afirmam que o esquema proposto pode ser útil como suporte na tomada de decisão em lavouras de maçã.

Mewes et al. (2011) usaram imagens hiperespectrais aéreas capturadas na faixa de 400-2450 nm para detectar oídio em campos de trigo. Os autores usaram a distância de Bhattacharyya para selecionar as bandas mais relevantes na separação entre regiões saudáveis e infectadas, e dois algoritmos de classificação (mapeador de ângulo espectral e máquinas de vetores suporte) para classificar os dados. Eles reportaram bons resultados, ressaltando a seleção de apenas algumas poucas bandas, foi uma das principais responsáveis pelo sucesso do algoritmo.

Li et al. (2011) construíram um sistema hiperespectral capaz de capturar imagens na faixa de 400-1000 nm para detectar defeitos em laranjas. Usando ACP, os autores selecionaram as 6 bandas mais apropriadas. A partir dessas bandas, a detecção dos defeitos se deu pela simples aplicação de um limiar. O índice de acertos foi superior a 90%, sendo que não houve casos de falsos positivos. Segundo os autores, a única desvantagem do algoritmo foi sua incapacidade de diferenciar os diferentes tipos de defeitos.

Moshou et al. (2011) propuseram um sistema multissensor que inclui um analisador de reflexão espectral, um imageador multiespectral de 4 bandas (3 no espectro visível mais 1 no infravermelho), e um imageador hiperespectral. A integração de todos os dados foi realizada pela aplicação de redes neurais. O objetivo foi criar um método automático para detecção e tratamento de doenças causadas por fungos em lavouras. Os testes foram realizados com a detecção de ferrugem amarela em trigo, revelando que o sistema tem potencial para ser utilizado no monitoramento não supervisionado, em tempo real, de lavouras.



Hillnhütter et al. (2011) usaram um esquema de classificação supervisionada chamado Mapeador de Ângulo Espectral, Spectral Angle Mapper (SAM), para, a partir de imagens capturadas por aviões em 126 bandas distribuídas na faixa de 450-2500 nm, detectar os estresses causados por *Heterodera schachtii* e *Rhizoctonia solani* em campos de beterraba. Os índices de acerto ficaram em torno de 70%, o que, segundo os autores, indicam que esta técnica pode ser utilizada na detecção destas doenças de maneira rápida e barata.

Os mesmos autores (HILLNHÜTTER et al., 2012) testaram a detecção dessas duas mesmas doenças em plantas de beterraba, porém, neste caso, usando imagens hiperespectrais capturadas em laboratório na faixa de 400-1000 nm. Os resultados indicaram um sucesso relativo, sendo que os autores indicaram que mais testes em condições de campo necessitariam ser realizados para indicar o uso do método proposto na aplicação pretendida.

Li et al. (2012) usaram dois diferentes espectrômetros, o primeiro capturando imagens na faixa de 348-2505 nm e sendo usado em campo, e o segundo capturando imagens na faixa de 200-2500 nm e sendo usado em laboratório. As imagens geradas por esses equipamentos foram utilizadas na detecção da doença Huanglongbing (HLB) em árvores de citros. Segundo os autores, métodos mais simples de classificação, como distância mínima e distância de Mahalanobis, resultaram nas detecções mais balanceadas e estáveis.

Mahlein et al. (2012) aplicaram imagens hiperespectrais na faixa de 400-1000 nm para fazer uma análise em escala local dos sintomas produzidos por três diferentes doenças em beterraba, ou seja, eles buscaram identificar diferentes características dentro de uma mesma lesão a fim de coletar mais informações sobre o problema afetando a planta. Segundo os autores, a união das reflectâncias espectrais com o mapeador de ângulos espectrais permitiu a divisão de sintomas em zonas apresentando todos os estágios ontogênicos, desde sintomas jovens até maduros.

Tian e Zhang (2012) usaram 1024 bandas na faixa de 400-1100 nm para a detecção de míldio em pepineiros. Análise de componentes principais foi combinada com fusão de imagens no nível de pixels e morfologia matemá-

tica para a realização da detecção do míldio. Segundo os autores, a taxa de acerto ficou próxima de 90%.

A possibilidade de se utilizar imagens hiperespectrais no infravermelho próximo para monitorar a qualidade da moagem de trigo a partir da análise de grãos individuais foi investigada por Delwiche et al. (2013). Os autores investigaram o uso de cinco atributos morfológicos e três atributos espectrais para estimar três diferentes indicadores de qualidade. Os resultados indicaram, apesar de haver uma boa correlação entre as propriedades hiperespectrais e os indicadores de qualidade, estes não são suficientemente fortes para que os métodos convencionais de controle possam ser substituídos.

Menesatti et al. (2013) usaram imagens hiperespectrais capturadas na banda de 400-790 nm para testar um sistema de detecção precoce de giberela em espigas de duas cultivares de trigo. Os dados espectrofotométricos foram analisados usando ferramentas de estatística multivariada, e os resultados indicaram que o método proposto pelos autores teve desempenho superior à análise visual realizada em campo.

Serranti et al. (2013) usaram reflectâncias espectrais capturadas na faixa do infravermelho próximo (1000-1700 nm) para diferenciar grãos de trigo normais, danificados por giberela e com nanismo amarelo. Os autores usaram técnicas como Análise de Componentes Principais (ACP) e Análise de Discriminante (AD), para seleção dos melhores comprimentos de onda e para a classificação das amostras. Os autores reportaram índices de erro baixos, indicando que a técnica proposta é apropriada para um rápido controle de qualidade dos grãos.

O método proposto por Barbedo et al. (2015) para detecção da giberela em grãos de trigo individuais usa imagens capturadas na faixa de 528-1785 nm, sendo que apenas 5 comprimentos de onda específicos foram utilizados. O método usa apenas operações morfológicas e operações aritméticas simples para fornecer uma estimativa numérica para a presença de giberela, chamada Índice Giberela. O algoritmo também demonstrou alguma capacidade para estimar a concentração de deoxinivalenol (DON) em grãos de trigo.

## Reflectância Hiperespectral

Um dos primeiros trabalhos a aplicar técnicas hiperespectrais em fitopatologia foi proposto por Malthus e Madeira (1993). Nesse trabalho, a reflectância de feijoeiros na faixa de 400-1100 nm foi capturada e usada na detecção do fungo *Botrytis fabae*. Os autores concluíram que as derivadas primeiras das reflectâncias produziram os melhores resultados, porém a detecção só foi possível quando os sintomas já começavam a se manifestar visualmente.

Bravo et al. (2003) usaram dados espectrais capturados na faixa de 300-2500 nm, normalização de irradiância e um esquema de discriminação quadrática para detectar ferrugem amarela em folhas de trigo. As imagens usadas nos testes foram capturadas diretamente no campo, usando um veículo desenvolvido pelos próprios autores, e o índice de acerto alcançado nos testes foi de 96%.

Muhammed e Larsolle (2003) exploraram a informação contida no espectro da reflectância hiperespectral de plantas de trigo para detectar doenças fungais. Os autores trataram o espectro como uma mistura de sinais independentes, aplicando Análise de Componentes Independentes (ICA) para separar as fontes independentes. Eles também aplicaram Análise de Componentes Principais (PCA) para extrair informações adicionais. Todas essas informações foram então interpretadas usando Análise Baseada em Vetores de Atributos. Os autores argumentaram que os resultados produzidos pelo algoritmo se correlacionam de maneira proporcional com a severidade das doenças analisadas. Muhammed (2005), numa continuação de seu trabalho anterior, publicou resultados usando as mesmas técnicas para quantificar a severidade de doenças fungais em trigo.

O método proposto por Moshou et al. (2004) fez uso de reflectâncias hiperespectrais na faixa de 460 a 900 nm para detecção automática de ferrugem amarela no dossel de plantas de trigo. Os autores propuseram um método de normalização para compensação de diferenças de iluminação, um método para visualização das propriedades espectrais usando mapas auto-organizáveis, e um método de detecção de doenças baseado em redes neurais. O índice de acerto alcançado foi de 95% a 99%, dependendo do conjunto de dados considerado.

Os mesmos autores (MOSHOU et al., 2005) propuseram um sistema terrestre de sensoriamento remoto fundindo reflectâncias hiperespectrais na faixa de 450-900 nm com imageamento por fluorescência. O objetivo do sistema foi detectar ferrugem amarela em plantas de trigo de inverno. Os autores testaram classificadores baseados em análise de discriminante quadrática e em mapas auto-organizáveis, sendo que estes últimos forneceram os melhores resultados, com índices de erro inferiores a 1%. Os mesmos autores (MOSHOU et al., 2006) publicaram outro trabalho na mesma linha dos anteriores, porém aqui o objetivo principal foi não apenas detectar estresses causados por doenças, mas também distingui-los dos efeitos causados por deficiências nutricionais.

Steddom et al. (2005) usaram dados de reflectância na faixa de 456-1080 nm para quantificar a severidade da cercosporiose em plantações de beterraba. Vários índices de vegetação foram calculados e comparados com as avaliações visuais realizadas para as plantas usadas nos testes. Segundo os autores, bons resultados em termos de acuidade e reprodutibilidade foram obtidos em muitos dos casos testados.

A quantificação de danos causados pelo pulgão verde em plantas de trigo de inverno foi o principal foco do trabalho de Yang et al. (2005). Os autores usaram informações espectrais na faixa de 450-1750 nm, sendo que estas foram utilizadas diretamente para detecção dos danos. Os melhores resultados foram obtidos para as bandas entre 600 e 900 nm.

A quantificação de danos causados pelo pulgão verde foi também o foco do trabalho de Mirik et al. (2006). As reflectâncias hiperespectrais foram capturadas na faixa de 339-1015 nm diretamente no campo. Os autores testaram diversos índices de vegetação, chegando à conclusão de que vários deles forneceram boas estimativas, porém nenhum mostrou uma clara vantagem sobre os outros em todas as situações.

Os mesmos autores (MIRIK et al., 2007) buscaram determinar as características espectrais dos danos causados pelo pulgão-russo-do-trigo usando informações espectrais do mesmo tipo daquelas usadas no trabalho anterior. Vários índices de vegetação foram testados, e análises de regressão linear mostraram que o chamado índice de afídeos, proposto pelos próprios autores, mostrou a melhor capacidade de quantificar os danos causados

pelo pulgão. Um estudo na mesma linha foi publicado pelos autores em 2012 (MIRIK et al., 2012), porém fazendo uma diferenciação nos resultados obtidos para trigo plantado em áreas irrigadas, áreas secas e estufas.

Delalieux et al. (2007) usaram dados hiperespectrais capturados na faixa de 350-2500 nm para detectar estresses bióticos em macieiras. Os autores usaram regressão logística, análise discriminante e modelagem baseada em árvores para selecionar as bandas mais apropriadas para diferenciar folhas saudáveis e doentes, chegando à conclusão de que as bandas entre 1350–1750 nm e 2200–2500 nm têm as melhores capacidades de detecção de infecções em seus estágios iniciais.

O trabalho publicado por Larsolle e Muhammed (2007) teve como objetivo apresentar e avaliar um método multivariado para análise objetiva hiperespectral no exame de como diferentes partes do espectro de reflectância são afetados pela severidade de doenças. Para isso, os autores utilizaram reflectâncias capturadas em campos de trigo e cevada, considerando 164 bandas entre 360 e 900 nm. Segundo eles, os bons resultados, aliados à simplicidade e à baixa complexidade computacional do método, fazem deste uma boa opção para o monitoramento de lavouras.

Xu et al. (2007) capturaram imagens hiperespectrais na faixa de 800-2500 nm usando a técnica baseada na transformada de Fourier, as quais foram utilizadas para detectar danos causados pelo bicho mineiro em folhas de tomateiros. Parâmetros espectrais como reflectância em um único comprimento de onda, área de pico e índice da banda de água foram usados para medir a severidade das lesões. Segundo os autores, a faixa de 1450 a 1900 nm foi a mais bem sucedida na tarefa.

Wang et al. (2008) coletaram dados espectrais contidos em 224 bandas na faixa de 400-2500 nm para detectar infecção por *Phytophthora infestans* em tomateiros. As imagens foram capturadas tanto em campo quanto por sensoriamento remoto aéreo. Os autores usaram redes neurais para realizar a classificação em plantas saudáveis e doentes, alcançando índices de acerto entre 60% e 70%.

Devadas et al. (2009) testaram 10 diferentes índices de vegetação, calculados a partir de dados de reflectância espectral na faixa de 400-900 nm,

para detecção de ferrugem em folhas de trigo; os dados usados nos testes foram capturados em laboratório, e os resultados indicaram que os melhores níveis de detecção foram obtidos pela combinação de três índices: a) índice de reflectância de antocianina; b) absorção de clorofila transformada; c) índice de reflectância.

Jones et al. (2010) propuseram um método para detecção de mancha bacteriana em tomateiros tendo como base em reflectâncias hiperespectrais na faixa de 200-2500 nm. Os comprimentos de onda mais significativos foram identificados por meio de uma análise por regressão de mínimos quadrados parciais, de uma análise do espectro do coeficiente de correção e de um procedimento de regressão linear múltipla. Bons resultados indicaram que este método tem potencial para ser usado no monitoramento de tomateiros.

Grisham et al. (2010) usaram um espectrógrafo de 2048 bandas na faixa de 350-800 nm para detectar o vírus da folha amarela em plantas de cana-de-açúcar antes da doença se expressar. Resultados usando análise discriminante mostraram que as técnicas usando reflectância das folhas e dados pigmentares foram capazes de prever a infecção pelo vírus em 73% e 80% dos casos, respectivamente, considerando dois diferentes cultivares de cana-de-açúcar.

Lelong et al. (2010) usaram um espectrorradiômetro, capaz de capturar imagens de 256 bandas espectrais na faixa de 310-1130 nm, para avaliar a infestação por doenças fúngicas em árvores de palma. As informações espectrais foram então relacionadas às condições sanitárias das plantas por meio de regressão por mínimos quadrados parciais e análise discriminante linear. O índice de acerto na classificação das árvores em quatro categorias de severidade chegou a 94%, indicando o sucesso da técnica empregada.

Liu et al. (2010) analisaram panículas de arroz usando um espectrofotômetro capaz de capturar imagens na faixa de 350-2500 nm. O objetivo foi quantificar os níveis de infecções causadas por fungos. Os autores aplicaram análise de componentes principais (ACP) para extrair os componentes principais de diferentes métodos de processamento espectral. A classificação das regiões em uma das 4 classes de severidade foi realizada por

uma rede neural com aprendizado por quantização vetorial, com índices de acerto ultrapassando os 90%.

A técnica proposta por Mahlein et al. (2010) visa detectar e identificar três diferentes doenças que atacam beterraba, cercosporiose, oídio e ferrugem, usando dados hiperespectrais na faixa de 400-1050 nm. Três diferentes atributos foram extraídos, o índice de vegetação NDVI, o índice de reflexão de antocianina e a integral de absorção de clorofila. Segundo os autores, esses índices têm diferentes capacidades de discriminação dependendo do tipo de doença, de modo que um sistema completo deve incluir uma combinação destes para ser efetivo.

O método adotado por Rumpf et al. (2010) empregou um espectroradiômetro capaz de capturar dados espectrais na faixa de 400-1050 nm para detectar e diferenciar três doenças que atacam plantas de beterraba: a) cercosporiose; b) ferrugem das folhas; e c) oídio. A classificação foi realizada por máquinas de vetores suporte usando funções de base radial como *kernel* e recebendo em suas entradas vários índices de vegetação. Os índices de acerto alcançados ficaram entre 65% e 90%, dependendo dos tipos de imagens e número de doenças considerados.

Yang (2010) usou dados de reflectância na faixa de 350-2500 nm para avaliar a severidade da infecção por mancha bacteriana em arroz. A correlação entre os dados espectrais e dois diferentes cultivares de arroz se mostrou suficientemente elevada para indicar o uso desta técnica, para este fim.

A detecção dos danos causados pela cigarrinha em plantações de algodão foi o principal objetivo de Prabhakar et al. (2011). Eles utilizam um sistema de reflectância hiperespectral na faixa de 350-2500 nm, sendo que seis bandas particulares mostraram a maior correlação com o grau de infestação. A partir dessas bandas, 22 índices foram testados, sendo que 2 mostraram potencial para serem utilizados na estimação da severidade dos danos causados pela cigarrinha.

Sankaran e Ehsani (2011) extraíram, a partir de dados hiperespectrais na faixa de 350-2500 nm, bandas de reflectância espectral e índices de vegetação. Os atributos foram extraídos utilizando dois métodos, análise de

discriminante por passos e análise de regressão por passos. Os atributos foram usados em dois classificadores, análise de discriminante quadrática e modelagem independente de analogias de classificação. Os autores observaram índices de acerto acima de 80% em todos os casos considerados.

Huang et al. (2012) empregaram dados hiperespectrais capturados na faixa de 325-1075 nm para detectar plantas de arroz danificadas pelo inseto *Cnaphalocrocis medinalis*. As imagens foram capturadas tanto no nível das folhas quanto no nível do dossel. Os autores observaram alterações espectrais em todas as bandas espectrais testadas e, com o uso de regressão linear, eles foram capazes de estimar o grau de severidade dos danos.

Shi et al. (2012) usaram dados hiperespectrais capturados na faixa de 900-1700 nm para construir mapas de distribuição de clorofila em folhas de pepineiros, os quais, por sua vez, foram utilizados para diagnosticar deficiência de nitrogênio. A informação espectral foi extraída utilizando análise de componentes principais, e modelos de calibração relacionando os espectros com a concentração de clorofila foram construídos usando regressão multilinear. Os autores reportaram uma alta correlação entre as estimativas fornecidas pelo algoritmo proposto e os valores reais de clorofila.

Zhang et al. (2012) usaram medidas de reflectância espectral na faixa de 350-1050 nm para detectar míldio em trigo de inverno. A partir desses dados, os autores extraíram 32 atributos espectrais, e usaram dois modelos de regressão, regressão linear multivariada e regressão de mínimos quadrados parciais, para estimar a severidade da infecção. Adicionalmente, eles empregaram análise de discriminante linear de Fisher para discriminar entre três níveis de saúde da planta. Os índices de acerto obtidos foram superiores a 90%.

A comparação entre atributos espectrais convencionais e atributos baseados em wavelets na detecção de ferrugem amarela em trigo foi o principal objetivo do trabalho publicado por Zhang et al. (2014). Ambos os tipos de atributos foram extraídos a partir de dados de reflectância espectral capturados na faixa de 350-2500 nm. Os autores concluíram que os atributos baseados em *wavelets* possuem uma melhor correlação com a presença da doença em folhas de trigo.



## Discussão

Como se pode observar, os três tipos de abordagens têm sido largamente aplicados a problemas agrícolas, sendo que nenhuma delas demonstra clara vantagens sobre as outras em todas as situações. Assim, a escolha de qual técnica utilizar depende, primeiro, de uma cuidadosa análise das características do problema que se deseja resolver, e segundo, dos equipamentos disponíveis ou dos recursos disponíveis para sua aquisição.

O imageamento multiespectral pode ser dividido em três tipos: a) local; b) aéreo; e c) por satélite. O imageamento multiespectral local normalmente é realizado através de câmeras cujos princípios de funcionamento são similares àqueles presentes em câmeras fotográficas convencionais, apenas estendendo o espectro capturado para incluir também o infravermelho próximo. Esta é uma opção de baixo custo, especialmente se comparada às opções hiperespectrais (imageamento e reflectância). Além disso, possui um alto grau de mobilidade, conferindo grande flexibilidade de captura em laboratório, no campo e durante o processamento de produtos agrícolas para transporte e comercialização. Portanto, esta é uma boa opção quando se deseja fazer detecção e análise localizadas de doenças e outros problemas em produtos agrícolas, especialmente se há restrições de custos.

Os equipamentos de captura usados no imageamento multiespectral aéreo são similares àqueles usados localmente. Porém, como estes são usados embarcados em veículos aéreos (aviões, helicópteros, VANT's), fatores como peso do equipamento, sensibilidade a distorções por movimento, capacidade de georreferenciamento, etc., devem ser considerados. Esta opção é particularmente útil quando se deseja fazer um levantamento geral da prevalência de certos problemas em grandes áreas com boa resolução espacial, muitas vezes permitindo a detecção precoce de doenças.

O imageamento multiespectral por satélite possui algumas características particulares. Primeiro, ao invés de se adquirir equipamentos específicos para realizar as capturas, as imagens normalmente são adquiridas junto aos proprietários dos satélites capazes de realizar este tipo de captura (por exemplo, o *quickbird*). Segundo, as imagens são capturadas em certos intervalos de acordo com a órbita do satélite. A principal vantagem é que

se pode ter um histórico ao longo do tempo das propriedades espectrais das áreas de interesse, porém há sempre a possibilidade de se ter a interferência de fatores meteorológicos. Como no caso do imageamento aéreo, esta opção é útil quando se deseja monitorar grandes áreas, porém com a vantagem de não ser necessário construir um aparato para realizar as capturas, mas com a desvantagem desta opção em geral fornecer uma menor resolução espacial. Em outras palavras, esta opção se encaixa perfeitamente quando o problema que se deseja detectar e analisar produz padrões visíveis que se espalham por grandes áreas, o que torna muito difícil a detecção precoce de doenças, quando os sintomas ainda estão restritos a pontos isolados das lavouras.

No imageamento hiperespectral, as reflectâncias espectrais são medidas em um grande número de diferentes bandas e traduzidas em valores espacialmente individualizados (pixels). Assim, para cada uma dessas bandas, é gerada uma imagem na escala de cinza que traduz, de maneira visual, como a superfície sob análise se comporta para cada comprimento de onda. Este tipo de tecnologia requer o uso de aparatos complexos para garantir a correta captura, uma vez que eles funcionam de modo similar a escâneres, normalmente fazendo uma varredura linha-a-linha da superfície do objeto sob análise. Por esse motivo, esta opção tende a ser mais cara que os equipamentos multiespectrais. Quase todos os trabalhos citados no texto usaram equipamentos em solo para realizar as medições, mas alguns poucos trabalhos, particularmente na Alemanha, realizaram capturas aéreas. O imageamento hiperespectral permite que se faça uma análise refinada do comportamento espectral, sendo, portanto, particularmente útil na análise e detecção de problemas com assinaturas espectrais particulares difíceis de serem detectados visualmente ou mesmo usando imagens multiespectrais. Adicionalmente, o fato de as assinaturas espectrais serem apresentadas na forma de imagens faz com que seja possível aplicar técnicas de processamento digital de imagens, tornando possível descobrir padrões que do contrário poderiam não ser detectados.

O princípio de funcionamento dos equipamentos de reflectância espectral é similar àquele usado nos equipamentos de imageamento hiperespectral. Contudo, ao invés de organizar as informações em imagens, eles geram curvas contendo a resposta espectral encontrada para cada área

analisada. Essas respostas normalmente são usadas como informação intermediária para derivar índices capazes de revelar diferentes características, como o NDVI. As aplicações para as quais é vantajoso aplicar a reflectância espectral são as mesmas apontadas para o imageamento hiperspectral. A desvantagem desta abordagem é o fato de não ser possível aplicar técnicas de processamento de imagens. Como os custos dos equipamentos em ambos os casos são similares, tem-se observado uma gradual migração para o imageamento, o que pode ser observado pela comparação do número de trabalhos publicados nos últimos anos usando cada uma das técnicas.

## Conclusão

Este documento apresentou uma revisão bibliográfica de alguns dos principais trabalhos relacionados à aplicação de análise espectral na análise da sanidade de plantas. Os trabalhos foram divididos em três grupos principais: a) imageamento multiespectral; b) imageamento hiperspectral; c) reflectância hiperspectral.

Uma análise crítica dos trabalhos indicam que ainda há muito a ser feito e explorado nessa área, e avanços significativos são esperados à medida que os equipamentos de captura sejam aperfeiçoados e barateados. A principal tendência que vem sendo observada na área é que, gradualmente, os métodos baseados em reflectância hiperspectral deem lugar aos métodos baseados em imagens hiperspectrais. Isto ocorre porque estas últimas têm a vantagem de, além de carregar praticamente toda a informação contida nas primeiras, permitem o uso de poderosas técnicas de processamento de imagens na extração de informação.

## Referências

ALEIXOS, N.; BLASCO, J.; NAVARRON, F.; MOLTO, E. Multispectral inspection of citrus in real-time using machine vision and digital signal processors. **Computers and Electronics in Agriculture**, v. 33, n. 2, p. 121-137, Feb. 2002.

ARIANA, D.; GUYER, D. E.; SHRESTHA, B. Integrating multispectral reflectance and fluorescence imaging for defect detection on apples. **Computers and Electronics in Agriculture**, v. 50, n. 2, p. 148-161, Feb. 2006.

BAUER, S. D.; KORČ, F.; FÖRSTNER, W. The potential of automatic methods of classification to identify leaf diseases from multispectral images. **Precision Agriculture**, v. 12, n. 3, p. 361-377, June 2011.

BARBEDO, J. G. A.; TIBOLA, C. S.; FERNANDES, J. M. C. Detecting Fusarium head blight in wheat kernels using hyperspectral imaging. **Biosystems Engineering**, v. 131, p. 65-76, Mar. 2015.

BRAVO, C.; MOSHOU, D.; WEST, J.; MCCARTNEY, A.; RAMON, H. Early Disease Detection in Wheat Fields using Spectral Reflectance. **Biosystems Engineering**, v. 84, n. 2, p. 137-145, Feb. 2003.

COOPS, N.; STANFORD, M.; OLD, K.; DUDZINSKI, M.; CULVENOR, D.; STONE, C. Assessment of Dothistroma Needle Blight of Pinus radiata Using Airborne Hyperspectral Imagery. **Phytopathology**, v. 93, n. 12, 1524-1532, Dec. 2003.

CUI, D.; ZHANG, Q.; LI, M.; ZHAO, Y.; HARTMAN, G. L. Detection of soybean rust using a multispectral image sensor. **Sensing and Instrumentation for Food Quality and Safety**, v. 3, n. 1, p. 49-56, Mar. 2009.

CUI, D.; ZHANG, Q.; LI, M.; HARTMAN, G. L.; ZHAO, Y. Image processing methods for quantitatively detecting soybean rust from multispectral images. **Biosystems Engineering**, v. 107, n. 3, p. 186-193, Nov. 2010.

DAMMER, K. H.; MÖLLER, B.; RODEMANN, B.; HEPPNER, D. Detection of head blight (*Fusarium* spp.) in winter wheat by color and multispectral image analyses. **Crop Protection**, v. 30, n. 4, p. 420-428, Apr. 2011.

DELALIEUX, S.; AARDT, J.; KEULEMANS, W.; SCHREVEENS, E.; COPPIN, P. Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: Non-parametric statistical approaches and physiological implications. **European Journal of Agronomy**, v. 27, n. 1, p. 130-143, Jul. 2007.

DELWICHE, S. R.; SOUZA, E. J.; KIM, M. S. Limitations of single kernel near-infrared hyperspectral imaging of soft wheat for milling quality. **Biosystems Engineering**, v. 115, n. 3, p. 260-273, July 2013.

DEVADAS, R.; LAMB, D. W.; SIMPFENDORFER, S.; BACKHOUSE, D. Evaluating ten spectral vegetation indices for identifying rust infection in individual wheat leaves. **Precision Agriculture**, v. 10, n. 6, p. 1385-2256, Dec. 2009.

FRANKE, J.; MENZ, G. Multi-temporal wheat disease detection by multi-spectral remote sensing. **Precision Agriculture**, v. 8, n. 3, 161-172, Jun. 2007.

GRISHAM, M. P.; JOHNSON, R. M.; ZIMBA, P. V. Detecting Sugarcane yellow leaf virus infection in asymptomatic leaves with hyperspectral remote sensing and associated leaf pigment changes. **Journal of Virological Methods**, v. 167, n. 2, p. 140-145, Aug. 2010.

GUYER, D.; YANG, X. Use of genetic artificial neural networks and spectral imaging for defect detection on cherries. **Computers and Electronics in Agriculture**, v. 29, n. 3, p. 179-194, Dec. 2000.

HILL, R. J.; WILSON, B. A.; ROOKES, J. E.; CAHILL, D. M. Use of high resolution digital multi-spectral imagery to assess the distribution of disease caused by *Phytophthora cinnamomi* on heathland at Anglesea, Victoria. **Australasian Plant Pathology**, v. 38, n. 2, p. 110-119, Mar. 2009.

HILLNHÜTTER, C.; MAHLEIN, A.-K.; SIKORA, R. A.; OERKE, E.-C. Remote sensing to detect plant stress induced by *Heterodera schachtii* and *Rhizoctonia solani* in sugar beet fields. **Field Crops Research**, v. 122, n. 1, p. 70-77, Apr. 2011.

HILLNHÜTTER, C.; MAHLEIN, A.-K.; SIKORA, R. A.; OERKE, E.-C. Use of imaging spectroscopy to discriminate symptoms caused by *Heterodera schachtii* and *Rhizoctonia solani* on sugar beet. **Precision Agriculture**, v. 13, n. 1, p. 17-32, Feb. 2012.

HUANG, J.; LIAO, H.; ZHU, Y.; SUN, J.; SUN, Q.; LIU, X. Hyperspectral detection of rice damaged by rice leaf folder (*Cnaphalocrocis medinalis*). **Computers and Electronics in Agriculture**, v. 82, p. 100-107, Mar. 2012.

JONES, C. D.; JONES, J. B.; LEE, W. S. Diagnosis of bacterial spot of tomato using spectral signatures. **Computers and Electronics in Agriculture**, v. 74, n. 2, p. 329-335, Nov. 2010.

KIM, Y.; GLENN, D. M.; PARK, J.; NGUGI, H. K.; LEHMAN, B. L. Hyperspectral image analysis for water stress detection of apple trees. **Computers and Electronics in Agriculture**, v. 77, n. 2, p. 155-160, July 2011.

KRAFT, M.; WEIGEL, H.-J.; MEJER, G.-J.; BRANDES, F. Reflectance Measurements of Leaves for Detecting Visible and Non-visible Ozone Damage to Crops. **Journal of Plant Physiology**, v. 148, n. 1-2, p. 148-154, 1996.

LARSOLLE, A.; MUHAMMED, H. H. Measuring crop status using multivariate analysis of hyperspectral field reflectance with application to disease severity and plant density. **Precision Agriculture**, v. 8, n. 1, p. 37-47, Apr. 2007.

LELONG, C. C. D.; ROGER, J.-M.; BRÉGAND, S.; DUBERTRET, F.; LANORE, M.; SITORUS, N. A.; RAHARJO, D. A.; CALIMAN, J.-P. Evaluation of Oil-Palm Fungal Disease Infestation with Canopy Hyperspectral Reflectance Data. **Sensors**, v. 10, n. 1, 734-747, Jan. 2010.

LI, J.; RAO, X.; YING, Y. Detection of common defects on oranges using hyperspectral reflectance imaging. **Computers and Electronics in Agriculture**, v. 78, n. 1, p. 38-48, Aug. 2011.

LI, X.; LEE, W. S.; LI, M.; EHSANI, R.; MISHRA, A. R.; YANG, C.; MANGAN, R. L. Spectral difference analysis and airborne imaging classification for citrus greening infected trees. **Computers and Electronics in Agriculture**, v. 83, p. 32-46, Apr. 2012.

LIU, D.; KELLY, M.; GONG, P. A spatial-temporal approach to monitoring forest disease spread using multi-temporal high spatial resolution imagery. **Remote Sensing of Environment**, v. 101, n. 2, p. 167-180, Mar. 2006.

LIU, Z.-Y.; WU, H.-F.; HUANG, J.-F. Application of neural networks to discriminate fungal infection levels in rice panicles using hyperspectral reflectance and principal components analysis. **Computers and electronics in agriculture**, v. 72, n. 2, p. 99-106, July 2010.

LIU, Y.; CHEN, Y. R.; WANG, C. Y.; CHAN, D. E.; KIM, M. S. Development of a simple algorithm for the detection of chilling injury in cucumbers from visible/near-infrared hyperspectral imaging. **Applied Spectroscopy**, v. 59, n. 1, p. 78-85, Jan. 2005.

MAHLEIN, A.-K.; STEINER, U.; DEHNE, H.-W.; OERKE, E.-C. Spectral signatures of sugar beet leaves for the detection and differentiation of diseases. **Precision Agriculture**, v. 11, n. 4, p. 413-431, Aug. 2010.

MAHLEIN, A.-K.; STEINER, U.; HILLNHÜTTER, C.; DEHNE, H.-W.; OERKE, E.-C. Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet diseases. **Plant Methods**, v. 8, n. 3, Jan. 2012.

MALTHUS, T.; MADEIRA, A. C. High resolution spectroradiometry: Spectral reflectance of field bean leaves infected by *Botrytis fabae*. **Remote Sensing of Environment**, v. 45, n. 1, p. 107-116, June 1993.

MENESATTI, P.; ANTONUCCIA, F.; PALLOTTINO, F.; GIORGI, S.; MATERE, A.; NOCENTE, F.; PASQUINI, M.; D'EGIDIO, M. G.; COSTA, C. Laboratory vs. in-field spectral proximal sensing for early detection of Fusarium head blight infection in durum wheat. **Biosystems Engineering**, v. 114, n. 3, p. 289-293, Mar. 2013.

MEWES, T.; FRANKE, J.; MENZ, G. Spectral requirements on airborne hyperspectral remote sensing data for wheat disease detection. **Precision Agriculture**, v. 12, n. 6, p. 795-812, Dec. 2011.

MILLER, W. M.; THROOP, J. A.; UPCHURCH, B. L. Pattern recognition models for spectral reflectance evaluation of apple blemishes. **Postharvest Biology and Technology**, v. 14, n. 1, p. 11-20, Sep. 1998.

MIRIK, M.; ANSLEY, R. J.; MICHELS JUNIOR, G. J.; ELLIOTT, N. C. Spectral vegetation indices selected for quantifying russian wheat aphid (*Diuraphis noxia*) feeding damage in wheat (*Triticum aestivum* L.). **Precision agriculture**, v. 13, n. 4, p. 501-516, Aug. 2012.

MIRIK, M.; MICHELS JUNIOR, G. J.; KASSYMZHANOVA-MIRIK, S.; ELLIOTT, N. C. Reflectance characteristics of Russian wheat aphid (Hemiptera: Aphididae) stress and abundance in winter wheat. **Computers and Electronics in Agriculture**, v. 57, n. 2, p. 123-134, July 2007.

MIRIK, M.; MICHELS JUNIOR, G. J.; KASSYMZHANOVA-MIRIK, S.; ELLIOTT, N. C.; CATANA, V.; JONES, D. B.; BOWLING, R. Using digital image analysis and spectral reflectance data to quantify damage by greenbug (Hemiptera: Aphididae) in winter wheat. **Computers and Electronics in Agriculture**, v. 51, n. 1-2, p. 86-98, Apr. 2006.

MOSHOU, D.; BRAVO, C.; WEST, J. S.; WAHLEN, S.; MCCARTNEY, A.; RAMON, H. Automatic detection of 'yellow rust' in wheat using reflectance measurements and neural networks. **Computers and Electronics in Agriculture**, v. 44, n. 3, p. 173-188, Sep. 2004.

MOSHOU, D.; BRAVO, C.; OBERTI, J.; WEST, J. S.; RAMON, H.; VOUGIOUKAS, S.; BOCHTIS, D. Intelligent multi-sensor system for the detection and treatment of fungal diseases in arable crops. **Biosystems Engineering**, v. 108, n. 4, p. 311-321, Apr. 2011.

MOSHOU, D.; BRAVO, C.; OBERTI, J.; WEST, J. S.; BODRIA, A.; MCCARTNEY, A.; RAMON, H. Plant disease detection based on data fusion of hyper-spectral and multi-spectral fluorescence imaging using Kohonen maps. **Real-Time Imaging**, v. 11, n. 2, p. 75-83, Apr. 2005.

MOSHOU, D.; BRAVO, C.; WAHLEN, S.; WEST, J. S.; MCCARTNEY, A.; BAERDEMAEKER, J. de; RAMON, H. Simultaneous identification of plant stresses and diseases in arable crops using proximal optical sensing and self-organising maps. **Precision Agriculture**, v. 7, n. 3, p. 149-164, July 2006.

MUHAMMED, H. H. Hyperspectral Crop Reflectance Data for characterising and estimating Fungal Disease Severity in Wheat. **Biosystems Engineering**, v. 91, n. 1, p. 9-20, Apr. 2005.

MUHAMMED, H. H.; LARSOLLE, A. Feature Vector Based Analysis of Hyperspectral Crop Reflectance Data for Discrimination and Quantification of Fungal Disease Severity in Wheat. **Biosystems Engineering**, v. 86, n. 2, p. 125-134, Oct. 2003.

OBERTI, R.; MARCHI, M.; TIRELLI, P.; CALCANTE, A.; IRITI, M.; BORGHESE, A.N. Automatic detection of powdery mildew on grapevine leaves by image analysis: Optimal view-angle range to increase the sensitivity. **Computers and Electronics in Agriculture**, v. 104, p. 1-8, June 2014.

OERKE, E.-C.; FRÖHLING, P.; STEINER, U. Thermographic assessment of scab disease on apple leaves. **Precision Agriculture**, v. 12, n. 5, p. 699-715, Oct. 2011.

POLDER, G.; VAN DER HEIJDEN, G. W. A. M.; DOORN, J. van; BALTISSEN, A. H. M. C. Automatic detection of tulip breaking virus (TBV) in tulip fields using machine vision. **Biosystems Engineering**, v. 117, p. 35-42, Jan. 2014.

POLDER, G.; VAN DER HEIJDEN, G. W. A. M.; DOORN, J. van; CLEVERS, J. G. P. W.; VAN DER SCHOOR, R.; BALTISSEN, A. H. M. C. Detection of the tulip breaking virus (TBV) in tulips using optical sensors. **Precision Agriculture**, v. 11, n. 4, p. 397-412, Aug. 2010.

PRABHAKAR, M.; PRASAD, Y. G.; THIRUPATHI, M.; SREEDEVI, G.; DHARAJOTHI, B.; VENKATESWARLU, B. Use of ground based hyperspectral remote sensing for detection of stress in cotton caused by leafhopper (Hemiptera: Cicadellidae). **Computers and Electronics in Agriculture**, v. 79, n. 2, p. 189-198, Nov. 2011. DOI: 10.1016/j.compag.2011.09.012.

QIN, J.; BURKS, T. F.; RITENOUR, M. A.; BONN, W. G. Detection of citrus canker using hyperspectral reflectance imaging with spectral information divergence. **Journal of Food Engineering**, v. 93, n. 2, p. 183-191, July 2009. DOI: 10.1016/j.jfoodeng.2009.01.014 .

QIN, J.; BURKS, T. F.; KIM, M. S.; CHAO, K.; RITENOUR, M. A. Citrus canker detection using hyperspectral reflectance imaging and PCA-based image classification method. **Sensing and Instrumentation for Food Quality and Safety**, v. 2, n. 3, p. 168-177, Mar. 2008. DOI: 10.1007/s11694-008-9043-3.

RUMPF, T.; MAHLEIN, A.-K.; STEINER, U.; OERKE, E.-C.; DEHNE, H.-W.; PLÜMER, L. Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. **Computers and Electronics in Agriculture**, v. 74, n. 1, p. 91-99, Oct. 2010. <DOI: 10.1016/j.compag.2010.06.009>.

SANKARAN, S.; EHSANI, R. Visible-near infrared spectroscopy based citrus greening detection: Evaluation of spectral feature extraction techniques. **Crop Protection**, v. 30, n. 11, p. 1508-1513, Nov. 2011. DOI: 10.1016/j.cropro.2011.07.005.

SERRANTI, S.; CESARE, D.; BONIFAZI, G. The development of a hyperspectral imaging method for the detection of Fusarium-damaged, yellow berry and vitreous Italian durum wheat kernels. **Biosystems Engineering**, v. 115, n. 1, p. 20-30, May 2013. DOI: 10.1016/j.biosystemseng.2013.01.011.

SHI, J.-Y.; ZOU, X.-B.; ZHAO, J.-W.; WANG, K.-L.; CHEN Z.-W.; HUANG X.-W.; ZHANG D.-T.; HOLMES, M. Nondestructive diagnostics of nitrogen deficiency by cucumber leaf chlorophyll distribution map based on near infrared hyperspectral imaging. **Scientia Horticulturae**, v. 138, p. 190-197, May 2012. DOI:10.1016/j.scienta.2012.02.024.



STEDDOM, K.; BREDEHOEFT, M. W.; KHAN, M.; RUSH, C. M. Comparison of visual and multispectral radiometric disease evaluations of *Cercospora* leaf spot of sugar beet. **Plant Disease**, v. 89, n. 2, p. 153-158, Feb. 2005. DOI: <http://dx.doi.org/10.1094/PD-89-0153>.

TIAN, Y.; ZHANG, L. Study on the methods of detecting cucumber downy mildew using hyperspectral imaging technology. **Physics Procedia**, v. 33, p. 743-750, 2012. DOI: 10.1016/j.phpro.2012.05.130.

WANG, X.; ZHANG, M.; ZHU, J.; GENG, S. Spectral prediction of *Phytophthora infestans* infection on tomatoes using artificial neural network (ANN). **International Journal of Remote Sensing**, v. 29, n. 6, p. 1693-1706, Mar. 2008. Disponível em: <<http://www.cab.zju.edu.cn/ics/faculty/zhuj/paper/E77.pdf>>. Acesso em: 20 set. 2015.

XU, H. R.; YING, Y. B.; FU, X. P.; ZHU, S. P. Near-infrared Spectroscopy in detecting Leaf Miner Damage on Tomato Leaf. **Biosystems Engineering**, v. 96, n. 4, p. 447-454, Apr. 2007. DOI: 10.1016/j.biosystemseng.2007.01.008.

YANG, C.-M. Assessment of the severity of bacterial leaf blight in rice using canopy hyperspectral reflectance. **Precision Agriculture**, v. 11, n. 1, p. 61-81, Feb. 2010. DOI 10.1007/s11119-009-9122-4.

YANG, Z.; RAO, M. N.; ELLIOTT, N. C.; KINDLER, S. D.; POPHAM, T. W. Using ground-based multispectral radiometry to detect stress in wheat caused by greenbug (Homoptera: Aphididae) infestation. **Computers and Electronics in Agriculture**, v. 47, n. 2, p. 121-135, May 2005. DOI: 10.1016/j.compag.2004.11.018.

ZHANG, J.-C.; PU, R.-L.; WANG, J.-H.; HUANG, W.-J.; YUAN, L.; LUO, J.-H. Detecting powdery mildew of winter wheat using leaf level hyperspectral measurements. **Computers and Electronics in Agriculture**, v. 85, p. 13-23, July 2012. DOI: 10.1016/j.compag.2012.03.006.

ZHANG, J.; YUAN, L.; PU, R.; LORAAMM, R. W.; YANG, G.; WANG, J. Comparison between wavelet spectral features and conventional spectral features in detecting yellow rust for winter wheat. **Computers and Electronics in Agriculture**, v. 100, p. 79-87, Jan. 2014. DOI: 10.1016/j.compag.2013.11.001.



---

*Informática Agropecuária*